

PAPER DETAILS

TITLE: DOGRUSAL VE DOGRUSAL OLMAYAN MODELLERLE ENFLASYON ÖNGÖRÜSÜ:
DURAGAN VE DURAGAN OLMAMANIN ETKİLERİ

AUTHORS: Nuri UÇAR,Nezir KÖSE,Sezgin AKSOY

PAGES: 45-56

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/287693>

DOĞRUSAL VE DOĞRUSAL OLMAYAN MODELLERLE ENFLASYON ÖNGÖRÜSÜ: DURAĞAN VE DURAĞAN OLMAMANIN ETKİLERİ

Nuri UÇAR*

Nezir KÖSE***

Sezgin AKSOY***

ABSTRACT:

In this paper we investigate Turkish inflation forecast performance for nine alternative statistical models, particularly focusing on the effects of both linearity and stationarity. Moreover, out of sample forecasts obtained through the models having minimum root mean square errors are combined with using fixed and varying weights approaches. We conclude that the combination of forecasts of the nonstationary artificial neural network and the nonstationary vector autoregressive model have the best one-ahead forecast performance for Turkish inflation.

Key Words : Inflation Forecast, VAR, Artificial Neural Network, Nonlinear Models

1. Giriş

Son yıllarda yapılan öngörü çalışmaları (Bkz. Gonzalez ve Moral,1995; Bidarkota,1998; Arino ve Franses, 2000) göstermektedir ki doğrusal ve doğrusal olmayan modellerin öngörü performansları farklılaşmaktadır. Ayrıca, değişkenlerin zaman serisi özellikleri de (durağan-durağan olmama) öngörüler üzerinde etkili olmaktadır. Bu çalışmada, enflasyon öngörü performansı açısından doğrusal ve doğrusal olmayan modellerin karşılaştırılması, değişkenlerin durağan ve durağan olmamasının etkileri ve farklı model öngörülerinin birleştirilmesinin öngörü başarısına katkısı araştırılmıştır. Çalışmada, yapay sinir ağı yaklaşımı için çözümlemelerde MATLAB paket programı kullanılmış iken diğer tüm yaklaşımlar için MFIT paket programından yararlanılmıştır.

Çalışmanın organizasyonu yukarıda belirtilen hedefler çerçevesinde şu şekilde planlanmıştır. İkinci bölümde, çalışmada yer alan değişkenlere ait zaman serisi verilerinin özellikleri incelenmiştir. Üçüncü bölümde, enflasyon öngörüsünde kullanılan modeller:

- (i) Durağan ve durağan olmayan verilerle vektör otoregressif modeller
- (ii) Durağan ARMA modeli (Box-Jenkins metodolojisi)
- (iii) Durağan ve durağan olmayan verilerle yapay sinir ağları (Artificial Neural Network)
- (iv) Durağan olmayan verilerle doğrusal olmayan modeller

başlıkları altında ele alınmıştır. Değişkenlerin düzeydeki değerleri ile ifade edilen doğrusal olmayan modeller için denenen matematiksel formlardan dört tanesinin uygun olduğu sonucu elde edilmiştir. Böylece, enflasyon öngörüsünde kullanılan modellerin sayısı dokuz ile sınırlandırılmıştır. Dördüncü bölümde ise öngörü periyodu dört olmak

*Bilkent Üniversitesi, Ekonomi Bölümü, Doktora Öğrencisi

**Yrd. Doç. Dr., Gazi Üniversitesi, İ.İ.B.F. Ekonometri Bölümü

***Yrd. Doç. Dr., Gazi Üniversitesi, İ.İ.B.F. Ekonometri Bölümü

üzere öngörü başarısı en yüksek model "karekök ortalama hata kare (RMSE)" kriterine göre belirlenmiştir. Beşinci bölüm, öngörü başarısı yüksek olan modellerin birleştirilmesi yöntemiyle, öngörü performansının artırılmasına yönelik bilgileri içermektedir. Çalışma, elde edilen bulguların değerlendirilmesi ile sona ermektedir.

2. Verilerin Zaman Serisi Özellikleri


Çalışmada, enflasyonun göstergesi olarak toptan eşya fiyat endeksi ve açıklayıcı değişken olarak da döviz kuru (TL/\$) alınmıştır. Bu değişkenlere ilişkin veriler Ocak 1982-Haziran 2001 dönemlerini kapsayan aylık gözlemlerden oluşmaktadır. Değişkenlerin kodları aşağıdaki gibidir.

TEFE: Toptan Eşya Fiyat Endeksi (1987=100)

USD : Döviz Kuru (TL/\$)

Çalışma kapsamında yer alan değişkenlerin zamana göre eğilimleri, düzey, logaritmik dönüşüm ve logaritmik birinci sıra fark şeklinde Şekil 1. de verilmiştir.

Şekil 1: Değişkenlerin Zamana Göre Eğilimleri



Değişkenlerin düzeydeki eğilimi üssel büyüme şeklindedir. Logaritmik dönüşüm vasıtasıyla doğrusal trend içeren bir eğilim elde edilmiştir. Logaritmik birinci sıra fark serisindeki eğilim durağan bir yapıya işaret etmektedir. Ayrıca, Nisan-1994 ekonomik krizinin neden olduğu yapısal kırılma da net bir şekilde gözlenmiştir.

Değişkenlerin durağanlığı 1994 yılı Nisan ayında gözlenen kırılma nedeniyle Perron (1989) birim kök testi ile araştırılmıştır. Perron birim kök testi genişletilmiş Dickey-Fuller (ADF) regresyon eşitliğine 1994. Nisan ayında 1, diğer dönemlerde sıfır değerini alan kukla değişken ilave edilerek gerçekleştirilmiştir (Model A). Perron ADF eşitliği için uygun gecikme yapısı maksimum gecikme uzunluğu 12 olmak üzere Campbell-Perron (1991) tarafından önerilen yaklaşımla belirlenmiştir. Elde edilen bulgular Tablo.1 de verilmiştir. Perron ADF testi sonuçları hem TEFÉ hem de USD zaman serisinin logaritmik birinci sıra farkta birim kök içermediğini diğer bir ifadeyle durağan olduğunu göstermiştir.

Tablo.1: Perron Model (A) ADF Testi Sonuçları

Değişken Kodu	Gecikme Uzunluğu	ADF (trendli)
LTEFE	11	-1.5556
DLTEFE	10	-5.3733
LUSD	2	-0.9057
DLUSD	1	-15.5576

* $\alpha=0.01$ anlamlılık düzeyinde birim kök içermiyor

L: Logaritma, D: Birinci sıra fark

Perron testi için $\lambda=0.63 \pm 0.6$ olup $\alpha=0.01$ düzeyinde kritik değer -4.45 dir

3. Modellerin Tanımlanması

Çalışmada kullanılan modelleri dört katogoride toplamak mümkündür. Bunlar:

- (i) Durağan ve durağan olmayan vektör otoregressif modeller
- (ii) Durağan ARMA modeli (Box-Jenkins metodolojisi)
- (iii) Durağan ve durağan olmayan yapay sinir ağları (Artificial Neural Network)
- (iv) Doğrusal olmayan modeller

3.1. Vektör Otoregressif Modeller

VAR modelinin en iyi kullanımının öngörü olduğu şeklindeki görüşler oldukça yaygındır. Bunun nedeni VAR modelinde dışsal değişken olmadığından öngörü periyodu için dışsal değişkenler hakkında herhangi bir varsayıma gerek olmamasıdır. VAR model öngörülleri, tüm değişkenlerin gelecekteki davranışının örnek periyodundaki ile aynı kalacağı örtülü varsayımı üzerine tesis edilmektedir. Son yıllarda yapılan bir çok çalışma, yapısal ekonometrik ve VAR model öngörü performanslarını karşılaştırmakta ve ayrıca ilgili zaman serisi verilerinin durağan ve durağan olmamasının VAR model öngörülleri üzerindeki etkisini araştırmaktadır (Bkz. McNees,1986; Lupoletti ve Webb,1986; Webb,1995).

Durağan Olmayan Vektör Otoregressif (NSVAR) Modeli

Durağan olmayan zaman serileri LTEFE ve LUSD arasındaki dinamik ilişkide gecikme

yapısı maksimum gecikme uzunluğu 12 olmak üzere model seçim kriterlerinden Akaike bilgi kriteri (AIC) ve Schwartz kriteri (SC) kullanılarak belirlenmiştir. Gerek AIC gerek SC uygun gecikme uzunluğunu 2 olarak tahmin etmiştir. O halde, NSVAR modeli aşağıdaki gibi olacaktır.

$$LTEFE_t = c_0 + \sum_{i=1}^2 \alpha_i LUSD_{t-i} + \sum_{i=1}^2 \beta_i LTEFE_{t-i} + u_{1t}$$

$$LUSD_t = c_1 + \sum_{i=1}^2 \gamma_i LUSD_{t-i} + \sum_{i=1}^2 \theta_i LTEFE_{t-i} + u_{2t}$$

Durağan Vektör Otoregressif (SVAR) Modeli

Durağan zaman serileri DLTEFE ve DLUSD arasındaki dinamik ilişkide de gecikme yapısı AIC ve SC kullanılarak belirlenmiştir. AIC ve SC kriterlerinin her ikisi de uygun gecikme uzunluğunu 1 olarak tahmin etmiştir. Bu durumda, SVAR modeli aşağıdaki gibi olacaktır.

$$DLTEFE_t = a_0 + \gamma_1 DLUSD_{t-1} + \theta_1 DLTEFE_{t-1} + u_{1t}$$


$$DLUSD_t = a_1 + \tilde{\gamma}_1 DLUSD_{t-1} + \tilde{\theta}_1 DLTEFE_{t-1} + u_{2t}$$

3.2. Durağan ARMA Modeli (Box-Jenkins Metodoloji)


Box-Jenkins metodolojide, durağan zaman serisi DLTEFE nin otokorelasyon ve kısmi otokorelasyon fonksiyonları incelenerek verilere uygun model belirlenmiştir. DLTEFE değişkeni için otokorelasyon ve kısmi otokorelasyon fonksiyonlarının şekilleri aşağıda verilmiştir. Kısmi otokorelasyon fonksiyonunun istatistiksel olarak sadece gecikme 1'de sıfırdan farklı ve diğer gecikmelerde sıfır olması ve otokorelasyon fonksiyonunun da yine gecikme 1'den sonra istatistiksel olarak sıfır olup hızla azalan bir eğilime sahip olması, geçici uygun modelin AR(1) veya ARMA(1,1) olabileceğine işaret etmiştir. Bu iki modelden AR(1) modeli için yapılan Box-Ljung Q-testi sonuçları artıkların otokorelasyonlu olmadığı bulgusunu vermiştir. Ayrıca, bu modelin ARMA(1,1) modeline göre Akaike Bilgi Kriteri (AIC) değeri daha küçük olduğundan uygun modelin AR(1) olduğu kararlaştırılmıştır:

$$DLTEFE_t = \alpha + \phi DLTEFE_{t-1} + u_t$$

Şekil 2: DLTEFE İçin Otokorelasyon Fonksiyonu



Şekil 3: DLTEFE İçin Kısmi Otokorelasyon Fonksiyonu



3.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA), özellikle konuşma, görüntü tanıma, karar verme, öğrenme ve kontrol gibi işlemlerin beyinde nöron adı verilen sinir hücreleri tarafından nasıl gerçekleştirildiğini açıklamak için geliştirilen doğrusal olmayan modellerdir. Yapay sinir ağları, genelleştirilmiş doğrusal modeller, polinomial regresyon, parametrik olmayan regresyon ve diskriminant analizi gibi istatistiksel tekniklerle benzerlik göstermektedir.

Yapay sinir ağları, basit olarak girdi (X), ağırlıklar (w), sapma (?), çıktı (Y) birimlerinden oluşur. Nöronlar ise bu birimleri bir araya getiren merkezlerdir (Hill ve diğerleri, 1994). Girdi vektörü (T), girdi ile ağırlıkların birbiri ile çarpılması ve bu çarpıma sabit bir sapma değerinin eklenmesiyle elde edilir

$$T = X'w + \theta$$

Girdi vektörüne sigmoid lojistik fonksiyon dönüşümü yapılarak çıktı vektörü elde edilir. Bu dönüşüm nöronlarda gerçekleşir ve lojistik dönüşüm fonksiyonu aşağıdaki gibidir:


$$Y = 1/(1 + e^{-T})$$

Yapay sinir ağlarında, parametre (ağırlıklar) tahminleri ve sapmaların düzeltilmesi öğrenme (learning) mekanizması içinde gerçekleştirilir. Parametrelerin sürekli güncellenmesi ise hedef çıktı (target output) ile tahmin edilen çıktı arasındaki farkın (hatanın) karelerinin minimize edilmesi yoluyla yapılır. Minimum hatayı veren uygun parametreler elde edilinceye kadar iterasyon devam eder.

Diğer yandan, YSA'da çıktı vektörü q tane dönüşüm nöronu için şu şekilde ifade edilebilir:

$$O_f = X'w + \sum_{i=1}^q \lambda'F_i(X'w)$$

Burada, çıktı vektörü, doğrusal olmayan dönüşüm fonksiyonu, girdi vektörü ve ise her bir dönüşüme karşılık gelen parametre vektörüdür. Yapay Sinir Ağlarının çalışma mekanizması aşağıdaki şekilde gösterilmiştir.



Şekil 4: İleri Beslemeli (feedforward) Sinir Ağlarının Genel Yapısı.

Bu şekil aşağıda sırasıyla açıklanan adımları ifade etmektedir:

ADIM 1. Girdiler ve hedef çıktı sisteme girilir.

ADIM 2. YSA girdilerine rassal olarak ağırlıklar atanır.

ADIM 3. Girdiler, nöronlar tarafından doğrusal olmayan fonksiyon ile dönüştürülürler.

ADIM 4. Dönüştürülen verilere uygun parametreler belirlenir.

ADIM 5. Tahmin edilen çıktı ile hedeflenen çıktı arasındaki farkın karesi belirli bir minimum değere ulaşınca kadar parametreler yeniden belirlenir.

ADIM 6. Tahmin edilen çıktılar bu çıktılara karşılık gelen parametrelerle birlikte elde edilir.

İktisat teorisi genelde iktisadi değişkenler arasında doğrusal olmayan ilişkilerin daha uygun olduğunu varsayar. İktisadi değişkenler üzerine yapılan öngörü çalışmalarında yapay sinir ağlarını da içeren doğrusal olmayan modellerin bazı değişkenler için doğrusal zaman serisi modellerine göre daha iyi öngörü performansına sahip oldukları gözlenmiştir (Bkz. Kohzadi ve diğerleri, 1996; Hill ve diğerleri, 1996). Diğer yandan, Swanson ve White (1997) bazı makroekonomik değişkenler için, geleneksel ekonometrik modeller ile YSA modellerinin öngörülerini karşılaştırmışlar ve değişkenler arasında doğrusal bir ilişki olmasına rağmen YSA modellerinin daha iyi öngörülere sahip oldukları sonucuna varmışlardır. Benzer bir karşılaştırma ise enflasyon oranı için Moshiri ve Cameron (2000) tarafından gerçekleştirilmiş ve YSA modellerinden göreceli olarak daha iyi öngörüler elde edilmiştir.

Doğrusal ve doğrusal olmayan zaman serisi modelleri çerçevesinde, durağanlığın öngörü performansına etkisi üzerine öngörü literatüründe sınırlı sayıda çalışma bulun-

maktadır. Bu durum dikkate alınarak çalışmada YSA modelleri durağan ve durağan olmayan olarak ikiye ayrılmıştır.


Durağan Olmayan Zaman Serileri İçin Yapay Sinir Ağı

Uygulama aşamasında durağan olmayan zaman serileri için oluşturulan Yapay Sinir Ağları modeli şekil.5'de verilmiştir.

Bu YSA yapısının matematiksel formu ise aşağıdaki gibi olacaktır.

$$LTEFE_t = \lambda'X_t + \sum_{j=1}^{10} \gamma'G_j(\lambda'X_t) + \sum_{j=1}^{10} \beta'F_j(\gamma'G(\lambda'X_t))$$


Burada $X_t = LTEFE_{t-1}, LTEFE_{t-2}, LUSD_{t-1}, LUSD_{t-2}$ girdi vektörüdür. Ayrıca, herbir nöron seti 10 nöron içermektedir. Doğrusal olmayan dönüşümler ise sigmoid fonksiyonu () ile gerçekleştirilmiştir.



Şekil 5: Durağan Olmayan İleri Beslemeli Yapay Sinir Ağları Yapısı

Durağan Zaman Serileri İçin Yapay Sinir Ağı

Değişkenlerin durağan olarak sisteme girildiği YSA modelinin yapısı Şekil.6 da gösterilmiştir.



Şekil 6: Durağan İleri Beslemeli Yapay Sinir Ağları Yapısı

Matematiksel olarak ise şu şekilde ifade edilebilir:

$$DLTEFE_t = \lambda'X_t + \sum_{j=1}^{10} \gamma G_j(\lambda'X_t) + \sum_{j=1}^{10} \beta F_j(\gamma G(\lambda'X_t)) + \sum_{j=1}^5 \theta H_j(F(\gamma G(\lambda'X_t)))$$

52

$X_t = DLTEFE_{t-1}, DLUSD_{t-1}$ girdi vektörüdür. Burada, durağan olmayan zaman serilerinden farklı olarak 3 tane nöron seti bulunmakta ve ilk iki set 10 nöron içerirken, sonuncu set 5 nöron içermektedir.

3.4. Doğrusal Olmayan Modeller

Doğrusal olmayan modeller, verilere uygun modelleme yöntemleri kullanılarak belirlenmiştir. Şekil 1. den de görüldüğü gibi TEFE ve USD değişkenlerinin zamana göre genel eğilimleri, azalan oranlarda sürekli artış gösteren bir yapıya sahiptir. Bu durum da dikkate alınarak dört farklı doğrusal olmayan matematiksel formdaki model çalışma kapsamına alınmıştır. Bu modellerin parametrelerine göre doğrusal olmaması nedeni ile parametrelerin tahmininde doğrusal olmayan en küçük kareler yöntemi kullanılmıştır (Bkz. Hannan, 1971; Gallant, 1987; Aksoy, 1996). Bu modeller aşağıdaki gibidir.

Model 1

$$TEFE_t = \exp(a_1(1/\sqrt{USD_t})) (TEFE_{t-1})^{a_2} (TEFE_{t-2})^{a_3} + u_t$$

Model 2

$$TEFE_t = a_1 + a_2 USD_t^{a_3} + u_t$$

Model 2 tahmin sonuçları elde edildiğinde Durbin-Watson (DW) istatistiğine göre artıklar arasında yüksek derecede otokorelasyon tespit edilmiştir. Artıkların otokorelasyon fonksiyonu incelendiğinde ilk iki gecikmeden sonra otokorelasyon katsayılarının hızlı bir şekilde sifıra yaklaştıkları görülmüştür. Hata teriminin ikinci dereceden otoregressif bir yapıya sahip olduğu varsayılarak model aşağıdaki formda ifade edilmiştir.

$$TEFE_t = a_1 + a_2 USD_t^{a_3} + a_4 (TEFE_{t-1} - a_1 - a_2 USD_{t-1}^{a_3}) + a_5 (TEFE_{t-2} - a_1 - a_2 USD_{t-2}^{a_3}) + u_t$$

Burada a_4 ve a_5 kısmi otoregressif katsayılarıdır.

Model 3

$$TEFE_t = \exp(a_1(1/\sqrt{USD_t}) + a_2(1/\sqrt{USD_{t-1}})) (TEFE_{t-1})^{a_3} (TEFE_{t-2})^{a_4} + u_t$$

Model 4

$$TEFE_t = a_1 \exp(a_2 T) + u_t$$

Burada T trend değişkenidir. Model 4 tahmin sonuçlarında artıklar incelendiğinde artıkların ikinci dereceden otoregressif yapıya sahip olduğu görülmüştür. Böylece, parametreleri tahmin edilecek model

$$TEFE_t = a_1 \exp(a_2 T) + a_3 (TEFE_{t-1} - a_1 \exp(a_2 (T-1))) + a_4 (TEFE_{t-1} - a_1 \exp(a_2 (T-2))) + u_t$$

olarak ifade edilmiştir. Burada a_3 ve a_4 kısmi otoregressif katsayılarıdır.

4. Modellerin Öngörü Performansları

Modellerin öngörü başarıları karekök ortalama hata kareler (RMSE) kriteri kullanılarak dört dönem sonrası periyoda kadar araştırılmıştır. Bu kriterin hesaplanmasında dönem dışı periyod olarak Ocak 1999-Haziran 2001 dönemleri alınmıştır. Her model için dönem dışı öngörülerin hesaplanmasında, en son veri ilave edilerek regresyonlar tekrarlanmıştır. Ayrıca, RMSE kriterinin hesaplanmasında öngörülerin logaritmik birinci sıra farkları kullanılmıştır. Böylece, değişkenlerin farklı düzeylerinde tanımlanan modellerin öngörülerini RMSE kriterine göre karşılaştırmak mümkün olmaktadır. Karekök ortalama hata kareler kriterine ilişkin sonuçlar Tablo.2'de verilmiştir.

Tablo 2 : RMSE Kriterine Göre Modellerin Öngörü Performansı

Modeller	Öngörü Periyodu			
	1	2	3	4
NSVAR	0.021965	0.030107	0.031113	0.031571
SVAR	0.020158	0.027677	0.028610	0.028814
AR(1)	0.028343	0.037011	0.039036	0.040553
Durağan Olmayan ANN	0.018211	0.017985	0.020184	0.05156
Durağan ANN	0.033489	0.049699	0.024925	0.028424
Doğrusal Olmayan Model 1	0.042711	0.079028	0.055172	0.043832
Doğrusal Olmayan Model 2	0.026457	0.055865	0.058905	0.043401
Doğrusal Olmayan Model 3	0.022571	0.043655	0.040720	0.031573
Doğrusal Olmayan Model 4	0.030607	0.043720	0.035873	0.042575

Tablo.2 incelendiğinde, ilk üç öngörü periyodu için durağan olmayan ANN, dördüncü öngörü periyodu için de durağan ANN modelinin daha iyi sonuçlar verdiği görülmüştür. Bu durum, enflasyon öngörüsünde "yapay sinir ağı" yaklaşımının daha iyi olduğuna işaret etmektedir. Ayrıca, durağan ve durağan olmayan verilerle gerçekleştirilen VAR yaklaşımında durağan VAR model öngörülerinin daha iyi sonuçlar verdiği görülmüştür. Doğrusal olmayan modeller arasında ise en iyi öngörü performansına sahip olan matematiksel form Model.3 olarak belirlenmiştir. Buna karşın, Tablo.3 de verilen "ortalama hata (ME)" değerleri bazı modellerin yukarı bazı modellerin ise aşağı doğru sapmalı öngörüler verdiğini göstermektedir. Bu sonuçlar, farklı model öngörülerinin birleştirilmesi vasıtasıyla enflasyon öngörü performansının artırılabilmesine dair bir kanıt olarak değerlendirilebilir.

Tablo 3 : ME Kriterine Göre Sonuçlar

MODELLER	Öngörü Periyodu			
	1	2	3	4
NSVAR	0.025498	0.058336	0.096748	0.137411
SVAR	0.032821	-0.000570	0.000692	0.000604
AR(1)	0.016284	0.044537	0.080042	0.119340
Durağan Olmayan ANN	0.033333	0.001038	0.000349	0.001775
Durağan ANN	0.008535	-0.003509	0.005081	0.001697
Doğrusal Olmayan Model 1	-0.000749	-0.010517	0.000956	0.008641
Doğrusal Olmayan Model 2	-0.002875	-0.003874	0.000239	0.006232
Doğrusal Olmayan Model 3	-0.000863	-0.003588	0.000561	0.005884
Doğrusal Olmayan Model 4	0.000615	-0.002348	0.000088	0.000638

5. Öngörülerin Birleştirilmesi

Alternatif model öngörülerinin birleştirilmesi yöntemiyle öngörü performansı artırılabilir (Granger, 1996, 2000). Bu çalışmada kullanılan ilk öngörü birleştirme yöntemi, farklı model öngörülerinin ağırlıklı ortalamasının alınmasıdır. Bu yaklaşım, öngörülerin birleştirilmesinde kullanılan ağırlıkların sabit olması nedeniyle sabit ağırlıklı yaklaşım olarak ifade edilmiştir.

P1 : Birinci modelin öngörü değerlerini, P2 : İkinci modelin öngörü değerlerini ve A gerçekleşen değerleri temsil etsin. Bu durumda, A* : Ağırlıklı ortalama öngörülere:

$$A^* = wP_1 + (1-w)P_2$$

olacaktır. Burada w ağırlıklardır. w'nin tahmini ise aşağıdaki formülle hesaplanır:

$$\hat{w} = \frac{\sum (A - P_2)^2}{\sum (A - P_1)^2 + \sum (A - P_2)^2}$$

Öngörülerin birleştirilmesinde kullanılan ikinci yaklaşım, öngörü hatalarının açıklayıcı değişken olarak kullanıldığı ve katsayıların değişimini de dikkate alan regresyon yaklaşımıdır. Bu yaklaşım, katsayıların değişmesi nedeniyle değişen ağırlıklar olarak ifade edilmiştir.

$$A_t = w_1 P_{1t} + w_2 P_{2t} + w_3 \lambda_{1t} P_{1t} + w_4 \lambda_{2t} P_{2t} + u_t$$

Burada

$$\lambda_{1t} = \begin{cases} 1 & A_t - P_{1t} < 0 \text{ ise} \\ 0 & \text{diğer durumlar} \end{cases} \quad \lambda_{2t} = \begin{cases} 1 & A_t - P_{2t} < 0 \text{ ise} \\ 0 & \text{diğer durumlar} \end{cases}$$

Çalışmada ele alınan modeller arasında bir dönem sonraki öngörü performansı daha yüksek olan durağan olmayan ANN, NSVAR ve SVAR öngörülere yukarıda açıklanan iki yaklaşım kullanılarak birleştirilmiştir. Bu birleştirme işlemi sonucunda elde edilen sonuçlar Tablo.4'de verilmiştir.

Elde edilen bulgular, birleştirme işlemi sonucunda RMSE kriterine göre öngörü başarısının arttığını göstermiştir. Çalışmada yer alan alternatif yaklaşım ve modeller içerisinde enflasyon öngörüsü başarısı en yüksek olanı "regresyon yaklaşımının kullanıldığı durağan olmayan ANN ve NSVAR" öngörülerinin birleştirilmesi ile elde edilmiştir.

Tablo 4. Öngörülerin Birleştirilmesinden Elde Edilen RMSE

Modeller	Sabit Ağırlıklı	Değişen Ağırlıklı
Durağan Olmayan ANN ve SVAR	0.019098	0.015158
Durağan Olmayan ANN ve NSVAR	0.021036	0.014734
NSVAR-SVAR	0.021903	0.022389

6. Sonuç

Araştırmanın ampirik bulgularından elde edilen sonuçlar maddeler halinde aşağıdaki gibi özetlenebilir:

- Çalışmada kullanılan modeller arasında enflasyon öngörüsü performansı RMSE kriterine göre en iyi olan "durağan olmayan ANN" modelidir.

- Durağan olmayan ANN ve NSVAR öngörülerinin birleştirilmesi yaklaşımı bir dönem sonraki enflasyon öngörü performansını arttırmıştır. Bir dönem sonraki enflasyon öngörü performansı en yüksek olan modele (Durağan olmayan ANN) göre "durağan olmayan ANN ve NSVAR" öngörülerinin değişen ağırlıklı regresyon yaklaşımı ile birleştirilmesi, RMSE değerinde %23.6'lık bir azalmaya neden olmuştur.
- Öngörülerin birleştirilmesinde sabit ağırlıkların kullanıldığı duruma kıyasla regresyon yaklaşımı (değişen ağırlıklar) daha iyi sonuç vermiştir.
- Durağan olmayan zaman serileri ile öngörü göreceli olarak daha başarılı sonuçlar vermiştir.
- Doğrusal olmayan (ANN) ve doğrusal (VAR) model öngörülerinin birleştirilmesi öngörü performansını arttırmıştır. Bu durum, doğrusal ve doğrusal olmayan modeller arasında bir seçim yerine, iki yaklaşımdan elde edilen öngörülerin birleştirilmesinin daha iyi sonuçlar verebileceğine işaret etmektedir.

KAYNAKÇA

- AKSOY, S., (1996), Otokorelasyonlu Hata Terimli Doğrusal Olmayan Regresyon Modellerinde Parametre Tahmini, (Basılmamış Doktora Tezi), G.Ü. Fen Bilimleri Enstitüsü, Ankara.
- ARINO, M. ve P.H. Franses, (2000), " Forecasting the levels of Vector Autoregressive Log-Transformed Time Series", International Journal of Forecasting, Vol.16, 111-116.
- BIDARKOTA, P.V., (1998), "The Comparative Forecast Performance Univariate and Multivariate Models: An Application to Real Interest Rate Forecasting", International Journal of Forecasting, Vol.14, 457-468.
- GALLANT, A. R., (1987), Nonlinear Statistical Models, Wiley: New York
- GONZALEZ P. ve P. MORAL, (1995), "An Analysis of International Tourism Demand in Spain", International Journal of Forecasting. Vol.15, 233-251.
- HANNAN, E. J., (1971), "Nonlinear Time Series Regression", Journal of Applied Probability, Vol 8, 767-780
- CAMPBELL, J.Y. ve P. PERRON, (1991), "Pitfall and Opportunities: What Macroeconomists Should Know About Unit Roots", In NBER Macroeconomics Annual 199 1, Edited by O.J. Blanchard ve S. Fischer, 144-201, Cambridge.
- DICKEY, D.A. ve W.A. FULLER, (1981), "Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root", Econometrica, Vol.49, 1057-1072
- GRANGER, C.W.J., (1996), "Can We Improve the Perceived Quality of Economic Forecasts", Journal of Applied Econometrics, Vol.11, 455-473.
- GRANGER, C.W.J, (2000), " Thick Modelling and Forecasting", METU Conference in Economics, Ankara, Turkey.
- HILL, T., L. MARQUEZ, M. O'CONNOR ve W. REMUS, (1994), "Artificial Neural Network Models for Forecasting and Decision Making", International Journal of Forecasting, Vol.10, 5-15.

KOHZADI, N. , M.S. BOYD, B.KERMANS SHAHI ve I. KAASTRA, (1996), "A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices" Neurocomputing, Vol.10, 169-181.

LUPOLETTI, W.M. ve R.H WEBB, (1986) Defining and Improving the Accuracy of Macroeconomic Forecasts: Contributions from a VAR Model, Journal of Business, 59, pp. 263-285.

MCNEES, S. K., (1986), "Forecasting Accuracy of Alternative Techniques: A Comparison of US Macroeconomic Forecasts", Journal of Business and Economic Statistics, Vol.4, 5-15.

MOSHIRI, S. Ve N.CAMERON, (2000) "Neural Network versus Econometric Models in Forecasting Inflation", Journal of Forecasting, Vol .19, 201-217.

PERRON, P., (1989), "The Great Crash, The Oil Price Shock, and The Unit Root Hypothesis", Econometrica, Vol.57, No.6, 1361-1401.

SWANSON, N. ve H. WHITE, (1997), "A Model Selection Approach to Real Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks", The Review of Economics and Statistics, Vol.1011, 540-550.

WEBB, R. H., (1995), "Forecasting of Inflation from VAR Models", Journal of Forecasting, Vol.14, 267-285.

T.C. Merkez Bankası, İstatistiksel Veri Tabanı, <[http: // www.tcmb.gov.tr/](http://www.tcmb.gov.tr/)>